

13-10-2021

Regularized Regression

Ridge Regression


$$Y = b_0 + b_1 X_1 + \dots + b_p X_p$$

$$b = \begin{pmatrix} b_0 \\ \vdots \\ b_p \end{pmatrix}$$

$$\min_b \text{RSS}(b) = \sum_{i=1}^N (y_i - b_0 - b_1 X_{i1} - \dots - b_p X_{ip})^2 = (y - Xb)^T (y - Xb)$$

$$\text{s.t.} \quad \sum_{j=1}^N b_j^2 \leq t$$

$$\text{n.x.} \quad Y = b_0 + b_1 X + b_2 X^2 + \dots + b_p X^p$$



① Scaling $b_1, \dots, b_p \Leftrightarrow X_1, \dots, X_p$

n.x. X_1 (σε km)

αν εκφρασει σε m $\Rightarrow X'_1 = 1000 \cdot X_1$

αρχικώ $Y = b_0 + b_1 X_1$

$$\gamma_1 = \frac{b_1}{1000}$$

νέο $Y = \gamma_0 + \gamma_1 \cdot 1000 X_1$

$$Y = b_0 + b_1 X_1 + \dots + b_p X_p$$

(a) Κανονικοποίηση $X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$ ($X'_i \in [0, 1]$)

$X_{\min} = \min \{X_i : i=1, \dots, N\}$

$X_{\max} = \max \{X_i : i=1, \dots, N\}$


(b) Τυποποίηση $\tilde{X}_i = \frac{X_i - \bar{X}}{\sigma(X)}$ $\bar{X} = \frac{X_1 + \dots + X_N}{N}$

$\tilde{\bar{X}} = 0$

$\sigma(\tilde{X}) = 1$

$\sigma(X) =$ υπ. απόκλιση των X στο δείγμα.

(2) Σταθερός όρος : b_0




Κεντρικοποίηση X_1, \dots, X_p

Στο μοντέλο $Y = b_0 + b_1 X_1 + \dots + b_p X_p$

οι εκτιμήσεις LS έχουν την ιδιότητα

$\bar{Y} = \hat{b}_0 + \hat{b}_1 \bar{X}_1 + \dots + \hat{b}_p \bar{X}_p$

$\bar{Y}, \bar{X}_1, \dots, \bar{X}_p$
(αποτελούν μέσοι του training set).



$$\hat{b}_0 = \bar{Y} - \hat{b}_1 \bar{X}_1 - \dots - \hat{b}_p \bar{X}_p$$

$$X_1^c = X_1 - \bar{x}_1, \dots, X_p^c = X_p - \bar{x}_p$$

$$x_{ij}^c = x_{ij} - \bar{x}_j$$

$$\hat{Y} = \hat{b}_0 + \hat{b}_1 X_1 + \dots + \hat{b}_p X_p$$

$$= \hat{b}_0 + \hat{b}_1 (X_1^c + \bar{x}_1) + \dots + \hat{b}_p (X_p^c + \bar{x}_p)$$

$$= \underbrace{(\hat{b}_0 + \hat{b}_1 \bar{x}_1 + \dots + \hat{b}_p \bar{x}_p)}_{\hat{y}} + \hat{b}_1 X_1^c + \dots + \hat{b}_p X_p^c$$

$$\Rightarrow \hat{Y} = \hat{y} + \sum_{j=1}^p \hat{b}_j X_j^c$$

Or $\bar{X}_j = 0 \Rightarrow$ αναιτιώτατα μέτρο b_1, \dots, b_p .

$$\min \text{RSS}(b) = (y - Xb)^T (y - Xb) \quad b = \begin{pmatrix} b_1 \\ \vdots \\ b_p \end{pmatrix}$$


$$\text{st.} \quad b^T b \leq t$$

$$(y - Xb)^T (y - Xb) = \text{RSS}(b) \leftarrow \text{κέραι (b)}.$$

$$\{b : b^T b \leq t\} : \text{κεραι σύνολο.}$$

Πρόβλημα
κεραι
προγραμ-
ματισμού

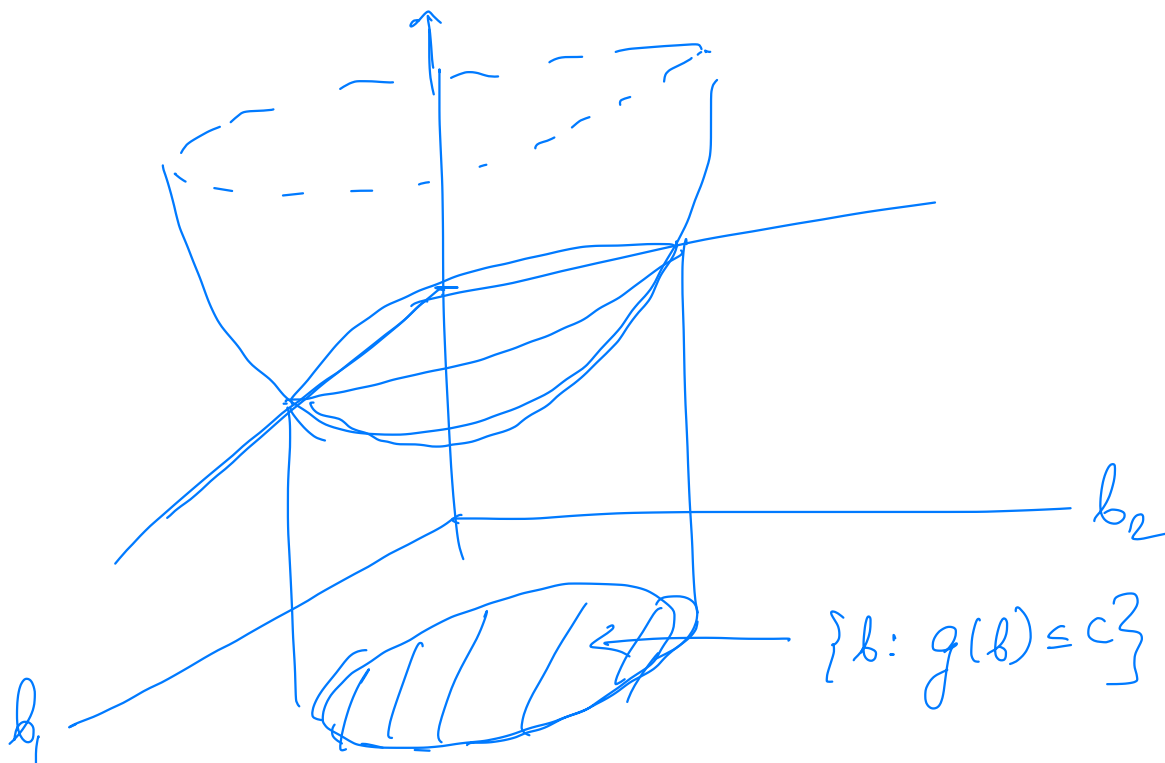
$A \subset \mathbb{R}^p$ κεραι



$$g(b) = b^T b : \text{κεραι συνάρτηση του } b$$

Θεώρημα Αν $g(b)$ κεραι ($b \in \mathbb{R}^p$)

$$\text{τότε } \forall c \in \mathbb{R} : \{b : g(b) \leq c\} \text{ κεραι σύνολο}$$



Lagrangean

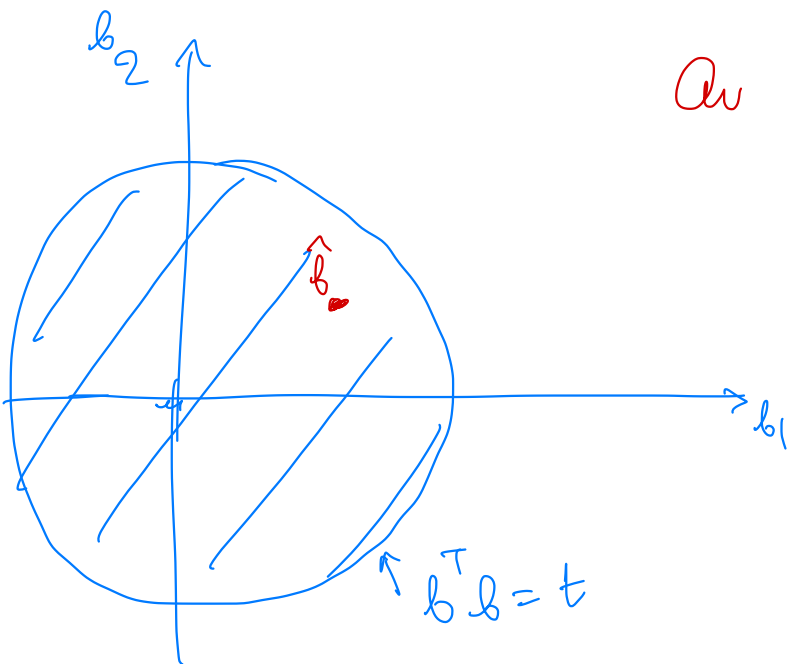
$$L(b, \lambda) = \text{RSS}(b) + \lambda (b^T b - t \leq 0)$$

Βέλτιστη λύση : $\frac{\partial L}{\partial b_j} = 0, j=1, \dots, P$

P εξισώσεις $\Rightarrow b_1^*(\lambda), b_2^*(\lambda), \dots, b_p^*(\lambda)$

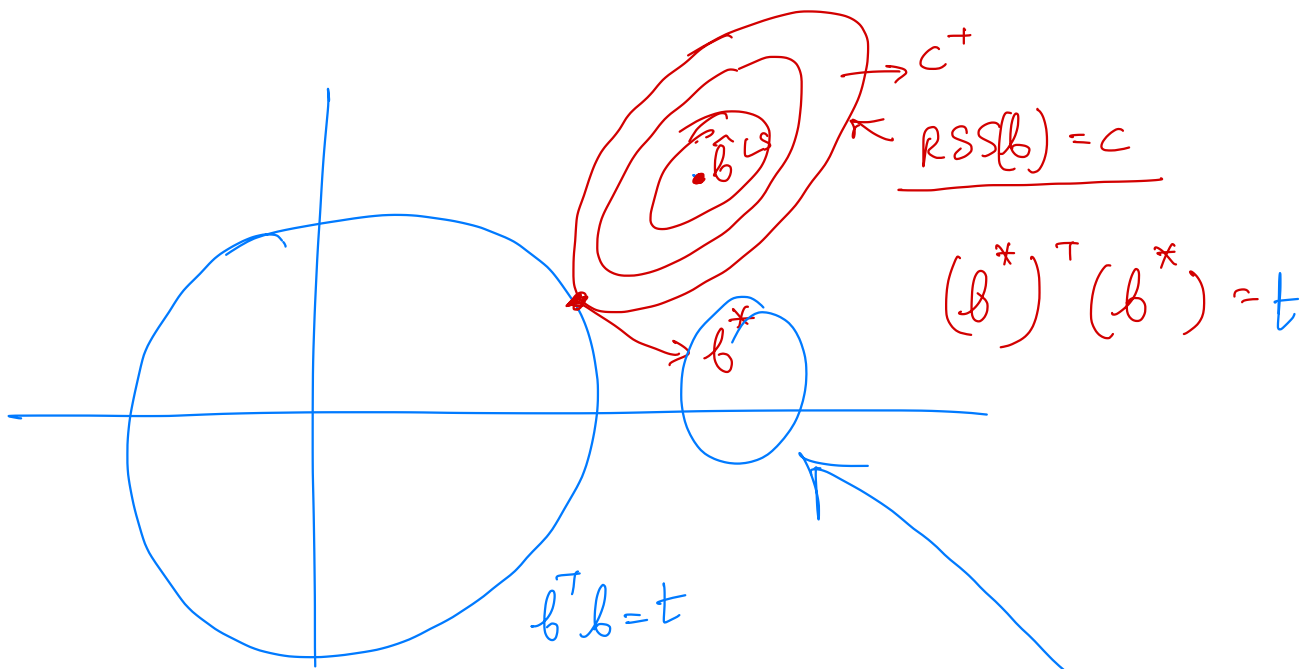
Για το λ :

Ερω \hat{b}^{LS} : 01 ΕΚΖ. Εφαχ. ζεραγ. $\min_b \text{RSS}(b)$



$$\text{ou } \left(\hat{b}^{LS} \right)^T \left(\hat{b}^{LS} \right) = t$$

$$\Rightarrow \underline{\hat{b}^* = \hat{b}^{LS}}, \lambda = 0.$$



Επιπέδων ΕΙΝΑΙ ΕΙΣΑΓΕΙΝ ΕΞΙΣΩΣΗ

$$\sum_{j=1}^p b_j^*(\lambda) = t \Rightarrow$$

$$\underline{\lambda^*(t)} \Rightarrow$$

$$\left\{ \begin{matrix} b_1^* \\ \vdots \\ b_p^* \end{matrix} \right\}$$

3 ~~μ~~ | - | αντιστρεψίμετο t k \rightarrow .

και ισοδύναμα

$$\min_b \left\{ \begin{array}{l} \text{RSS}(b) \\ \sum b_j^2 \leq t \end{array} \right\} \iff \min_b \left\{ \text{RSS}(b) + \lambda \sum_{j=1}^p b_j^2 \right\}$$

$$\min_b (y - Xb)^T (y - Xb) + \lambda b^T b = \text{RSS}(\lambda)$$

λ : παραμέτρος

$$\nabla_b \text{RSS} = -2 X^T y + 2(X^T X) \cdot b + 2\lambda b$$

$$= 2 \left[(X^T X + \lambda I) b - X^T y \right] = 0$$

$$\Rightarrow \hat{b}_{\text{ridge}} = (X^T X + \lambda I)^{-1} \cdot X^T y$$


$$\hat{b}^{\text{LSE}} = (X^T X)^{-1} \cdot X^T y$$

Lasso Regression

$$\begin{array}{l} \min \\ \text{st.} \end{array} \quad \begin{array}{l} \text{RSS}(b) \\ \sum_{j=1}^p |b_j| \leq t \end{array}$$



$$\min_{b_1, \dots, b_p} \text{RSS}(b) + \lambda \sum_{j=1}^p |b_j|$$



πρόβλημα
τετραγωνικού
προγραμματισμού

$$\begin{array}{l} b_1 + b_2 \leq t \\ -b_1 - b_2 \leq t \\ b_1 - b_2 \leq t \\ -b_1 + b_2 \leq t \end{array}$$

Ridge Regression

X

Singular value decomposition

$$X = U D V^T$$

$$X^T = V D U^T$$

D : διαγώνιος

U, V ορθογώνιοι

$$U^T U = I, V^T V = I$$

$$U, V \in \mathbb{R}^{N \times P}$$

$$X^T X = V D \underbrace{U^T U}_I D V^T = V D^2 V^T$$

$$D^{-2} = (D^2)^{-1}$$

$$(X^T X)^{-1} = V D^{-2} V^T$$

$$(V D^{-2} V^T)(V D^2 V^T) = I$$

LSE $\hat{b}^{\text{LSE}} = (X^T X)^{-1} X^T y =$

$$= V D^{-2} V^T V D U^T y = V D^{-1} U^T y$$

$$\hat{y}^{\text{LSE}} = X \hat{b}^{\text{LSE}} = \dots = \underline{U U^T y} = \sum_j u_j u_j^T \cdot y$$

$$\hat{y}^{\text{ridge}} = X \hat{b}^{\text{ridge}} = \dots = U \underbrace{D (D^2 + \lambda I)^{-1} D}_{\text{circled}} U^T y$$

$$= \sum_{j=1}^P u_j \left(\frac{d_j^2}{d_j^2 + \lambda} \right) u_j^T \cdot y \quad U = [u_1, \dots, u_P]$$

d_j = singular values του πίνακα X .

↳ ορίζονται ως κύριες συνιστώσες του X .

Ασκ. 2.1

G κανονική

$$\begin{cases} g_1 \\ \vdots \\ g_k \end{cases}$$

κωδικοποίηση

$$\begin{cases} (1, 0, \dots, 0) X_1 \\ \vdots \\ (0, 1, \dots, 0) X_k \end{cases}$$

$$y = b_0 + b_1 X_1 + \dots + b_k X_k$$

\hat{y} : predictions

$$\hat{G}_i =$$

$$\hat{y}_i =$$

$$\begin{pmatrix} \hat{y}_{i1} \\ \vdots \\ \hat{y}_{ik} \end{pmatrix}$$